

多种深度学习算法联合提高地震相分析及 油气储层预测效果

张 鑫¹, 雷德文¹, 李献民¹, 阎建国², 黄闻露²

(1. 中国石油新疆油田分公司勘探事业部, 新疆 克拉玛依 834000; 2. 成都理工大学 地球物理学院, 成都 610059)

摘要:联合使用多种深度学习算法,更好地挖掘地震数据中的隐蔽和有用信息,实现相互补充和优化,对于减少地震相分析结果的不确定性,具有重要意义。为此,提出了一种从标签训练到数据挖掘再到优化的全过程深度学习地震相分析的方法和流程。首先,通过自组织映射网络图(SOM)进行波形分类,为监督学习提供具有代表性的训练数据;然后,利用卷积神经网络(CNN)和循环神经网络(RNN)进行地震相分析,将预测得到的地震相分析结果输入到生成对抗神经网络(GAN)进行算法优化及运算结果的不确定性分析;最后,结合实际资料分析给出最优结果。本文提出和实现了SOM+CNN/RNN+GAN的监督和监督联合的深度学习地震相分析的方法及实用流程,通过在研究区河道砂体储层油气预测的实际应用,证明该方法提高了地震相分析及油气储层预测结果的可靠性及效果。

关键词:地震相分析;机器学习;GAN;不确定性分析;油气储层预测

中图分类号:TE19 **文献标志码:**A **文章编号:**1671-1807(2023)22-0262-06

地震相分析方法已经成为地震资料解释和储层预测的常用方法之一^[1]。近年来,利用深度学习算法更好的挖掘地震数据中的隐蔽和有用信息,帮助研究确定地震相的地质意义,引起人们的广泛关注,成为地震资料解释及储层预测的方法和应用研究的热点之一^[2-6];另外,地下地质目标十分复杂,地震响应特征和地质目标并不是一一对应^[7-9],并且判断地震相的地质意义受到人为因素影响从而具有很强的主观性。因此,利用多种深度学习算法是否有利于提高地震相分析结果的可靠性,成为基于深度学习算法的地震相分析方法和应用研究的重要研究方向^[10]。

Marroquin等^[11]系统介绍了利用自组织映射网络图(self-organizing map, SOM)进行波形分类地震相分析的方法技术和应用效果。SOM强大的聚类能力及其可以将高维数据映射低维数据,使其逐渐成为无监督波形聚类地震相分析的主流方法。在深度学习方法的发展下,于海鹏^[12]在将近一百张地震剖面中,通过人工识别的方式,划分出了5种不

同的地震相结构。张军华^[13]提取6种地震属性,将支持向量机(support vector machines, SVM)应用到储层预测中。乔英汉^[14]提出了一种基于半监督生成对抗网络(semi-supervised generative adversarial network, SGAN)的半监督地震相分析方法,利用生成对抗网络(generative adversarial networks, GAN)更有效地提取地震数据中的隐藏信息。半监督网络能够有效地利用有限标签,对没有标签的训练数据进行特征提取,改善训练结果^[15]。

机器学习算法在提高地震相分析的效率以及减少地震相预测中的不确定性方面也发挥了重要作用, Thilo等^[16]介绍了相关的最新成果, Kaur^[17]利用GAN对地震数据进行分割,同时在网络框架中加入不确定性分析,以此反映网络预测结果的置信度。

基于上述的国内外相关研究方向及研究成果,围绕进一步提高地震相分析结果的精度和可靠性等问题,本文提出和研究了一种从标签训练到数据挖掘再到结果优化的全过程深度学习地震相分析

收稿日期:2023-08-04

基金项目:中国石油集团重大专项(2019D-07)。

作者简介:张鑫(1972—),男,新疆克拉玛依人,中国石油新疆油田分公司勘探事业部,科长,高级工程师,研究方向为物探采集处理解释技术管理;雷德文(1963—),男,四川威远人,中国石油新疆油田分公司,首席物探技术专家,教授级高级工程师,博士,研究方向为地质地震综合研究及油气勘探;李献民(1965—),男,甘肃兰州人,中国石油新疆油田分公司勘探开发研究院,高级工程师,研究方向为物探采集技术管理;阎建国(1960—),男,山东广饶人,成都理工大学地球物理学院,教授,博士,研究方向为地震勘探方法技术及应用研究;黄闻露(1997—),女,湖南邵阳人,成都理工大学地球物理学院,硕士研究生,研究方向为油气地球物理勘探。

的方法和流程。首先用无监督的神经网络算法 SOM 进行波形分类,制作标签数据;然后利用卷积神经网络(convolutional neural network,CNN)和循环神经网络(recurrent neural network,RNN)等有监督的深度学习算法进行地震相分析,最后结合 GAN 对抗的思想实现各种算法的优化及结果的不确定性分析并结合实际资料分析给出最优结果。通过新疆阜东河道砂体油气储层预测的实际应用,取得了符合实际情况的良好效果,为研究区的储层综合研究提供了支撑。

本文提出的 SOM+CNN/RNN+GAN 监督和非监督联合的深度学习地震相分析方法和流程,实现了从标签训练到数据挖掘再到结果优化的全过程深度学习算法的应用,提高了地震相分析的智能化程度。

1 方法原理

深度学习算法可以概括为监督与非监督两种主要类型,两者的区别主要体现在训练时是否需要为其提供标签数据。有监督深度学习算法主要优点是更强大的数据挖掘或特征提取能力;无监督深度学习算法主要优点是无须标签数据,通过自主学习样本数据中的内在关系,完成数据挖掘。一般而言,地震相分析采用是一种“模式识别”的思想,因此有监督的深度学习算法对于深度挖掘地震相特征更有力^[18-20],但标签及训练数据集的产生方法、类型和质量等,直接影响有监督深度学习算法的效果。无监督学习不再需要大量的标签数据,利用聚类的思想,将属性本身作为训练数据。采用有监督和无监督联合的方法,完成了从标签制作,数据挖掘或特征提取,再到算法优化及结果优选的全过程深度学习。经过实验对比分析,最终选用了波形作为地震反射特征参数进行波形分类的地震相分析方法。

由于 SOM、CNN、RNN 的一般网络结构已被人们熟知,接下来重点介绍算法的数学表达和这些算法在地震相分析中的实现方法。

1.1 SOM 方法原理

SOM^[21]是一种应用较广泛的无监督型深度学习算法,模型由且仅由输入层和输出层组成。SOM 训练过程不同于一般神经网络基于损失函数的反向传递,它运用竞争学习策略,依靠神经元之间相互竞争,来选取最优匹配神经元(式 1)逐步优化网络,并且按照临近关系函数(式 2)维持输入空间的拓扑结构。

$$y_i = \operatorname{argmindiff}(\mathbf{x}, \mathbf{w}_i) \quad (1)$$

式中: $\mathbf{x}$ 为输入数据; $\mathbf{w}_i$ 为权重系数;输出节点 y_i 被称为“胜者节点”。

$$\operatorname{dist}(d) = \left(1 - \frac{d^2}{\theta^2}\right) \exp\left(-\frac{d^2}{2\theta^2}\right) \quad (2)$$

式中, θ 为尺度因子; d 为权重 $\mathbf{w}$ 与输入属性向量 $\mathbf{x}$ 的拓扑距离。

SOM 方法原理及其在波形分类的地震相分析中的应用效果,Chopra 和 Marfurt^[22]做过较系统的介绍。本文利用 SOM 方法原理,一方面进行地震相的无监督划分,提供一种地震相分析结果作为参考;另一方面,将该地震相分析结果作为标签和训练数据集的选择基础。从而可以得到一种快速自动的标签制作方法,为下一步的有监督深度学习算法创造条件。

1.2 CNN 方法原理

CNN 卷积神经网络通过多层卷积核的卷积运算,按照标签“模式”能够提取到样本的细节特征。卷积运算的基本数学表达如式(3)所示。卷积神经网络最重要的几个网络层分别为卷积层、激活层、池化层及全连接层。

$$x_j^l = f\left(\sum_{i \in M} x_j^{l-1} k_{ij}^l + b_j^l\right) \quad (3)$$

式中: l 为网络的层数; k 为卷积核; b 为输出特征图的偏置; f 为激活函数; x_j^l 为上层的某特征图; k_{ij}^l 为卷积核权值。

本文实现的地震相波形分类中,是将每个 $5 \times 5 \times d$ 的小三维数据体标注为一类,最终的输入数据为 N 个 $5 \times 5 \times d$ 的小的三维数据体。 N 为小三维数据体的个数; d 在这里表示的选取的时窗长度。

1.3 RNN 方法原理

考虑到地震信号属于一种时间序列信号,而 RNN 循环神经网络适用于时间序列信号的分析,因此研究了 RNN 的地震相分析适用性问题。采用对传统 RNN 改进的长短时记忆网络(long short-term memory,LSTM)实现波形分类的地震相分析。

LSTM 引入了遗忘门和记忆门的概念。可以根据前一时刻的记忆 x_{t-1} 和当前的输入 x_t ,决定修改输入的内容,也就是选择遗忘部分记忆。记忆门根据 x_{t-1} 的记忆和当前的输入 x_t ,决定增加哪些内容。

1.4 GAN 方法原理

生成对抗网络 GAN 采用一种“对抗”的思想进行机器学习。虽然没有标签数据,但通过对训练抗,使 GAN 学习到真实数据的特征。GAN 主要由生成模块和判别模块组成(图 1)。生成模块又叫作生成器(generator,G),负责依据输入向量产生判别内容。判别模块又叫作判别器(discriminator,D),主要用来分辨输入的信息是“真实”的数据,还是生成模块生成的“假”数据,输出一个概率值,代表着内容的真实程度。




图1 GAN网络结构

GAN的数学表达式为

$$GAN(G, D) = E_{x,y} [\ln D(x, y)] + E_{x,z} [\ln \{1 - D(x, G(x, z))\}] \quad (4)$$

式中： E 为熵； x 为输入； y 为真实数据的分布； z 为生成器的生成数据的分布； $D(x, y)$ 为鉴别器的值； $G(x, z)$ 为生成器的值。

1.5 基于GAN网络的算法优化及不确定性分析

利用GAN算法,实现了一种二维图像间的“对抗”分析,用于CNN和RNN地震相分析结果的对抗以及CNN不同标签下的地震相分析结果的对抗,进行了不确定性分析,实现了各种地震相分析方法的优化,提升了深度学习算法的地震相分析效果和可靠性。基于GAN网络进行的算法优化和不确定性分析,总体上有以下三种模式。

1)同一种算法结果的自身对抗:将CNN的训练结果为“真”,用相同CNN训练的结果去“对抗”。

2)不同算法之间对抗优化:用CNN的训练结果为“真”,RNN的训练结果去对抗和用RNN的训练结果为“真”,CNN的训练结果去对抗。

3)同一种算法不同参数所得结果之间的对抗优化:用CNN不同标签下所得结果的对抗优化。

实际资料应用中采用了SOM+CNN/RNN+GAN的监督与非监督联合的地震相分析方法,方法流程如图2所示。

2 应用效果

以新疆阜东某三维工区的河道砂体储层预测为例,说明所提出方法的应用效果。

2.1 研究区概况

新疆阜东5井区构造位置上属准噶尔盆地阜康




图2 监督与非监督地震相分析方法流程

凹陷的阜东斜坡区,东邻北三台凸起,北接白家海凸起,南接阜康断裂带,工区北部以沙漠为主,南部以农田为主,工区地势较为平坦,北高南低。

研究工区为阜东5三维工区的一部分(图3)。图3中的红框部分为研究的工区范围,图中的红白区域展示了河道砂体的分布。研究区主要目的层为侏罗系头屯河组二段的河道砂体储层。由图3和卞保力^[23]的研究可知,研究区河道发育,且分流河道网状交织,叠加样式多样,河道边界识别难度大,河道空间展布形态不清楚;由于阜东斜坡沉积环境与相带不同,河道砂体在储层评价的各方面都会表现出差异,包括砂体含油的流体饱和度等。




图3 研究区目的层段平均振幅属性

2.2 SOM波形分类制作标签

按照方法流程,首先利用SOM进行波形分类,并用这个分类结果作为标签制作和训练数据集选择的参考。虽然最后的地震相分析只分了7类,但考虑到应从尽可能多的分类中选择具有代表性的7类数据,首先利用SOM“大数据”分类,进行了21类分类,得到21类标签数据[图4(a)]及对应的训练数据集。根据已知信息挑选出7种具有代表典型模板波形[图4(b)]作为最后的标签数据。

按照目的层段视窗厚度,最终构建出了7个(5×5×目的层段时窗)大小的3维地震标签数据体及与之对应的7个训练数据体。

2.3 CNN和RNN地震相分析

我们将挑选出7种具有代表性的模板波形作为监督学习的标签数据,利用CNN和RNN网络结构进行地震相分析,得到地震相分析结果如图5和图6所示。

由图5和图6并对比图3可知,CNN和RNN的地震相结果都能刻画研究区的河道分布,但两种方法所刻画的河道数量和分布形态不完全一样,地震相分析结果存在不确定性。

2.4 GAN算法优化及不确定性分析

由于实际地下地质条件的复杂多变,地震相分

析结果与地质目标不是一一对应;用于监督算法的标签数据的不同也带来同一种算法不同的结果,即不确定性。针对不确定性选用 GAN(生成对抗网络),利用“对抗”的思想来实现不同算法之间、不同结果之间的“对抗”优化和不确定性分析。

实际资料应用中,将 CNN 的结果作为较为确定的数据,RNN 的结果作为不太确定的数据,输入到 GAN 网络中进行对抗,结果如图 7 示。由图 7 可知,相比于用 GAN 优化前的 RNN 地震相结果(图 6),优化后的地震相分析结果(图 7)对河道的反映更为清晰;对比 CNN 结果(图 5),优化后的地震相分析结果在河道形态反映上也有改进。基于 GAN 网络的地震相分析结果,在河道展布形态的识别上,




图 4 模板波形




图 5 研究区目的层段 CNN 波形地震相分析结果




图 6 研究区目的层段 RNN 波形地震相分析结果

给出更确定的河道分布。这些河道分布(图 7 中的黑色虚线框出区域)与工区内已知井的河道砂体地震反射特征分析结果相对应(表 1);平面上的河道特征与剖面上目的层段间的“透镜体”反射及地质上的认识对应,可以确定这些分类结果指示了河道,地震相平面图则展示河道的分布情况。综上分析,GAN 通过“对抗”,在优化了 RNN 结果的同时,也看到了 CNN 结果中的不确定性,使最后得到地震相分析结果更具有可靠性。

在确定了研究区目的层的河道分布后,结合研究区的已钻井和已知信息,进一步分析不同河道砂体的物性分布及含油气情况。图 8 为过 FD_05 井和 FD_051 井的地震剖面图,其上标注了已钻井的含油气情况。由图 7 可知,FD_05 井和 FD_051 井之间被另一条河道分割(图 7 中的白色框区域),结合图 8 已知钻井结果,由于另一条河道的叠置,造成原本处于同一条河道上的 FD_05 井和 FD_051 井处的砂体物性发




图 7 研究区目的层基于 GAN 网络得到的地震相分析结果

表 1 头屯河组二段地质地震特征

微相	分流河道	河口坝
岩石类型	中砂岩、细砂岩、粉砂岩	厚层、中厚层细砂岩或粉砂岩
测录井特征 (GR 为自然伽马/API; RT 为电阻率/($\Omega \cdot m$))		
典型井	阜东 052	阜东 5
地震反射特征	中、强振幅、中等频率、钟形反射波	强振幅、中低频、上旋反射波
井旁地震道		

生了变化,从而其砂体储层的含油气性也不相同。FD_05 井处为含油气有利砂体,FD_051 井砂体为含油气不利砂体。结合研究区内的已钻井和已知信息,完成了有利河道砂体的分布预测,预测了 I~IV 类有利储层(图 9)。FD_05 井所在河道为一类有利河道砂体;FD_052 井所在河道砂体为二类有利河道砂体;FD_10 井北部的河道为三类河道砂体;FD_051 井的河道为四类河道砂体。本次研究中所提供的有利河道砂体的预测结果,为后期的井位部署提供了依据。

3 结论

利用无监督 SOM 方法,提供一种地震相分析

的参考结果,并为监督学习算法提供有意义的标签数据,从而发挥了“模式识别”算法的优势,可以得到更精确的地震相分析结果。

基于 GAN 网络的“对抗”思想,进一步优化了不同算法地震相分析的效果,在一定程度上解决了不确定性问题。

本文提出的 SOM+CNN/RNN+GAN 的地震相分析方法及流程提高了地震相分析的精度和可靠度。实际资料应用表明,其结果能得到更加符合已知情况的砂体识别结果,为研究区的含油气有利砂体识别的综合研究提供了支撑。




图 8 过 FD_05 井和 FD_051 井的地震剖面




图 9 研究区头顿河组二段有利河道砂体综合预测

参考文献

- [1] SAFFAF M M, NAFI TOKSOZ M, MARHOON M I. Seismic facies classification and identification by comprtitve neural networks[J]. *Geophysics*, 2003, 68(6):1984-1999.
- [2] TOLSTAYA E, EGOROV A. Deep learning for automated seismic facies classification[J]. *Interpretation*, 2022, 10(2):SC31-SC35.
- [3] LIU M, JERVIS M, LI W, et al. Seismic facies classification using supervised convolutional neural networks and semi-supervised generative adversarial network[J]. *Geophysics*, 2020, 85(4):47-58.
- [4] WANG Y, WANG L, LI K, et al. Unsupervised seismic facies analysis using spare representation spectral clustering[J]. *Applied Geophysics*, 2020, 17(4):533-543.
- [5] 马陇飞, 肖汉敏, 陶敬伟, 等. 基于深度学习岩性分类的研究与应用[J]. *科学技术与工程*, 2022, 22(7):2609-2617.
- [6] 薛永超, 袁志乾, 金青爽, 等. 基于深度森林算法的油井产量预测[J]. *科学技术与工程*, 2022, 22(11):4327-4334.
- [7] HAMPSON D, TODOROV T, RUSSELL B, et al. Using multi-attribute transforms to predict log properties from seismic data[J]. *Exploration Geophysics*, 2000, 31:481-487.
- [8] 王剑, 刘金, 陈俊, 等. 准噶尔盆地东部石炭系优质火山岩储层特征及分布规律[J]. *科学技术与工程*, 2023, 23(22):9388-9403.
- [9] 刘昊琳, 卢志远, 李胜, 等. MH1 井区二叠系下乌尔禾组沉积微相及有利储层预测[J]. *科学技术与工程*, 2023, 23(18):7650-7660.
- [10] LI K, LIU Z, SHE B, et all. Prestack seismic facies analysis via waveform sparse representations[J]. *Geophysics*, 2021, 86(1):IM35-IM50.
- [11] MARROQUÍN I D, BRAULT J, HART B S. A visual data-mining methodology for seismic facies analysis[J]. *Geophysics*, 2009, 74(1):1-11.
- [12] 于海鹏. 卷积神经网络识别地震相方法研究[D]. 北京: 中国石油大学, 2016.
- [13] 张军华, 任雄凤, 赵杰, 等. 基于交叉验证 SVM 储层预测方法研究及应用[J]. *科学技术与工程*, 2020, 20(13):5052-5057.
- [14] 乔英汉. 面向地震相识别的生成对抗网络及其应用研究[D]. 北京: 中国石油大学, 2021.
- [15] BABAKHIN Y, SANAKOYEU A, KITAMURA H. Semi-supervised segmentation of salt bodies in seismic images using an ensemble of convolutional neural networks[C]//The 41th German Conference on Pattern Recognition. Dortmund Germany: Pattern Recognition, 2019:218-231.
- [16] THILO W, INDRANIL P, ROBERT L, et al. Seismic facies analysis using machine leraning[J]. *Geophysics*, 2018, 83(5):83-95.
- [17] KAUR H, PHAM N, SERGEY F. Seismic data interpolation using CycleGAN [C]//SEG Technical Program Expanded Abstracts 2019; Society of Exploration Geophysicists. Texas; San Antonio, 2019:2202-2206.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA; Institute of Electrical and Electronics Engineers, 2016:770-778.
- [19] YU S W, MA J W. Deep learning for geophysics: current and future trends[J]. *Reviews of Geophysics*, 2021, 59(3):1-36.
- [20] 肖立志. 机器学习数据驱动与机理模型融合及可解释性问题[J]. *石油物探*, 2022, 61(2):205-212.
- [21] KOHONEN T, SCHROEDER M R, HUANG T S. Self-organizing maps [M]. London: Springer Berlin Heidelberg, 2001.
- [22] CHOPRA S, MARFURT K J. Unsupervised machine learning applications for seismic facies classification [C]//Proceedings of the 7th Unconventional Resources Technology Conference. Denver, Colorado; Computer Science, 2019:3135-3142.
- [23] 卞保力. 基于高密度三维地震河道砂体储层预测方法研究与应用[D]. 成都: 成都理工大学, 2019.

A Joint Various Deep Learning Methods to Improve the Reliability of Seismic Facies Analysis and Reservoir Characterization Results

ZHANG Xin¹, LEI Dewen¹, LI Xianmin¹, YAN Jianguo², HUANG Wenlu²

(1. Exploration Division of PetroChina Xinjiang Oilfield Branch, Karamay 834000, Xinjiang, China;

2. Chengdu University of Technology, Chengdu 610059, China)

Abstract: It is of great significance to reduce the uncertainty of seismic phase analysis results by combining multiple deep learning algorithms to mine hidden and useful information in seismic data, and to achieve mutual complementarity and optimization. Therefore, a method and process of deep learning seismic phase analysis from label training to data mining to optimization were proposed. Firstly, waveform classification is performed by the SOM of the self-organizing mapping network diagram, which provides representative training data for supervised learning. Then, the convolutional neural network CNN and the circulating neural network RNN are used for seismic phase analysis, and the predicted seismic phase analysis results are input to the generative adversarial neural network GAN for optimization between algorithms and uncertainty analysis of operation results, and finally the optimal results are given based on actual data analysis. The method and practical process of SOM+CNN/RNN+GAN combined supervised and unsupervised deep learning seismic facies analysis are proposed and realized, and it is proved that the method improves the reliability and effect of seismic facies analysis and oil and gas reservoir prediction results through the practical application of oil and gas prediction in river channel sand reservoir reservoirs in the study area.

Keywords: seismic facies analysis; machine learning; GAN; uncertainty analysis; hydrocarbon reservoir characterization